

Gesetzmäßigkeiten im Chaos

Über das Langzeitgedächtnis und seine Folgen in Klima,
Physiologie und auf den Finanzmärkten

Von Sabine Lennartz und Armin Bunde



istockphoto


Wichtige Informationen über komplexe Systeme in der Natur erhalten wir oft aus Zeitreihen: Aus Temperatur- und Niederschlagsreihen erhoffen wir uns Aufschluss über globale Klimaänderungen, und aus medizinischen Zeitreihen wie der des Herzschlags oder des Blutdrucks kann man oft Rückschlüsse auf den Gesundheitszustand des Patienten ziehen. Aus der Analyse von Finanzreihen erhoffen wir uns eine Maximierung der Gewinnchancen sowie eine Minimierung des Verlustrisikos. In den letzten Jahren hat sich herausgestellt, dass in solchen Zeitreihen die Schwankungen der einzelnen Werte nicht voneinander unabhängig sind, sondern stattdessen über sehr lange Zeitspannen hinweg untereinander gekoppelt sind. Das heißt, die zugrunde liegenden Prozesse besitzen ein oft überraschend langes „Gedächtnis“. Von diesem Phänomen der Langzeitpersistenz, die gewisse universelle Züge trägt, und ihrer Bedeutung für die Risikoanalyse und der Abschätzung des globalen Klimawandels handelt dieser Artikel.

Schon seit geraumer Zeit wissen wir [1], dass Temperaturschwankungen über lange Zeitspannen hinweg miteinander gekoppelt sind. Das Klima besitzt ein „Gedächtnis“, das nur sehr langsam mit wachsendem zeitlichen Abstand s schwächer wird – etwa wie $(1-\gamma)s^{-\gamma}$, wobei γ angibt, wie schnell das Gedächtnis abfällt. Dieses Langzeitgedächtnis, für das u.a. wohl die Kopplung der Atmosphäre an die Ozeane und deren Trägheit verantwortlich ist, führt zu einer Erhaltungsneigung („Persistenz“) des Klimas: So wollen Abweichungen vom Mittelwert Bestand haben, was zu ausgeprägten und lang anhaltenden positiven oder auch negativen Abweichungen vom jeweiligen Mittelwert führt. Aus dem Alltag ist dieses Phänomen bekannt: Auf einen warmen bzw. kalten Tag folgt eher wieder ein zu warmer bzw. zu kalter Tag. Das Gleiche gilt aufgrund der Persistenz des Klimas auch für Monate, Jahre und Dekaden, allerdings mit abnehmender Tendenz.

Abbildung 1a zeigt die vorwiegend mit Hilfe von Baumringen rekonstruierte Moberg-Temperaturreihe für

die mittleren Jahrestemperaturen der nördlichen Hemisphäre zwischen den Jahren 1 und 1799. Als schwarze Linie ist der gleitende 30-jährige Mittelwert eingezeichnet. Die Persistenz-typischen Abweichungen vom Mittelwert sind deutlich zu erkennen. Um das Jahr 1000 herum und ab 1900 sind klare Warmphasen zu sehen und um 1600 eine ausgeprägte Kaltphase. Diese Berg-Tal-Struktur setzt sich auch auf kleineren Zeitskalen fort. Die Moberg-Reihe hat einen γ -Wert von ungefähr 0,3. Abbildung 1b zeigt im Vergleich eine künstlich erzeugte Reihe mit dem gleichen γ -Wert. Beide Abbildungen zeigen das gleiche charakteristische Berg-Tal-Verhalten.

Einzelne kontinentale Stationsdaten haben in der Regel einen γ -Wert ganz nahe bei 0,7, eine Eigenschaft, die gut als Test für Klimamodelle herangezogen werden kann [2]. Für Seetemperaturen sind γ -Werte um 0,3 typisch. Bei Niederschlagsdaten ist keine ausgeprägte Erhaltungsneigung zu erkennen, d.h. γ liegt nahe bei 1. Für Pegelstände von Flüssen gilt, dass auch sie über lange Zeiten hinweg persistent sind, mit γ um 0,3.



■ Abb. 1: Vergleich von (a) der Moberg-Reihe und (b) einer künstlich erzeugten langzeitpersistenten Reihe mit einem γ -Wert von ungefähr 0,3. Der gleitende 30-jährige Mittelwert ist in schwarz gezeichnet (nach: D. Rybski, A. Bunde, S. Havlin und H. v. Storch: Geophys. Res. Lett., 33, L 06718 (2006)).

■ Abb. 2: Patient bei einer EKG-Messung. Die scharfen Maxima im EKG (R-Peaks) zeigen die Kontraktionen der Herzhauptkammern an. Die zeitlichen Abstände zwischen zwei Maxima sind die Herzschlagintervalle.

Foto: Rolf Wegst

Herzschlag

In der Regel sind die Herzschlagintervalle, die sich mit einem EKG (siehe Abb. 2) messen lassen, bei Gesunden nicht konstant, sondern schwanken um einen mittleren Abstand von $\sim 0,6$ bis 1,0 Sekunden. Auch dieser Mittelwert selbst ist nicht konstant, sondern es sind langsame Trends und auch Sprünge zu beobachten, die beispielsweise durch unterschiedliche körperliche Belastung oder Aufregung verursacht werden können. Die Frage ist nun, wie sich die Schwankungen der Herzschlagintervalle charakterisieren lassen, und was man daraus über die Funktion und den Zustand des Herzkreislauf-Systems bzw. eventuelle Erkrankungen erfahren kann. Um die Trends und Sprünge im Herzrhythmus zu vermeiden, die durch willentliche




Einflüsse verursacht werden, ist es am geschicktesten, die Schwankungen während der Schlafphase zu untersuchen. Im Schlaf lassen sich verschiedene Phasen unterscheiden: Leichtschlaf, Tiefschlaf und REM-Schlaf, die sich abwechseln.

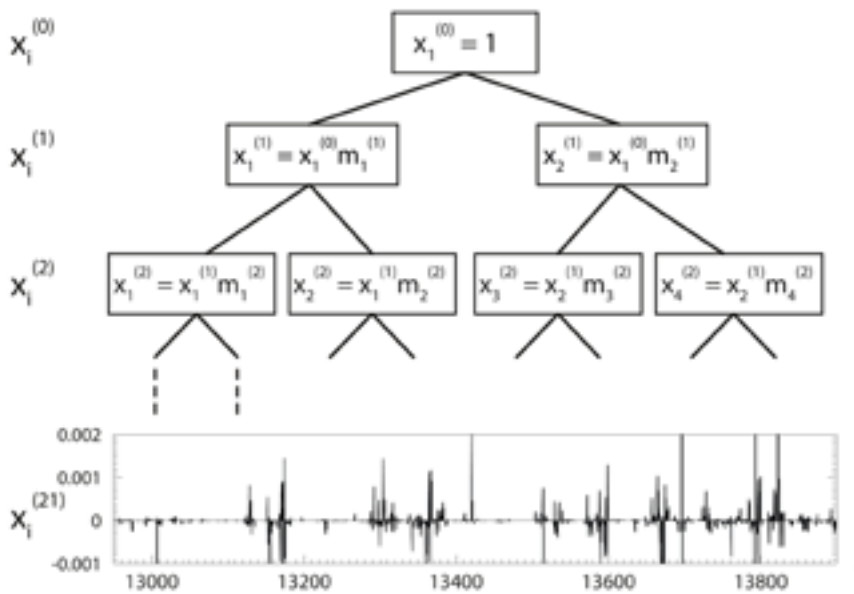
Während der Tiefschlaf hauptsächlich der physischen Erholung dient, benötigt man die REM-Phasen, die ihren Namen von den raschen Bewegungen der (geschlossenen) Augen haben (REM=rapid eye movement), hauptsächlich zur psychischen Erho-

lung und Gedächtnisverarbeitung; sie werden häufig mit dem Traumschlaf in Verbindung gebracht. Die Schlafphasen lassen sich in einem medizinischen Schlaflabor bestimmen, indem man die Gehirnströme, die Aktivität bestimmter Muskeln sowie die Augenbewegungen aufzeichnet.

Die Persistenzanalyse zeigt nun, dass die Herzschlagintervalle in den verschiedenen Schlafphasen einem ganz unterschiedlichen Rhythmus folgen. Während sie im REM-Schlaf eine starke Erhaltungsneigung besitzen ($\gamma \approx 0,3$) sind sie sowohl im Leicht- als auch im Tiefschlaf oberhalb charakteristischer Zeiten (die näherungsweise dem Atmungszyklus entsprechen) völlig regellos ($\gamma \approx 1$) [3]. Daher erscheint es durchaus möglich, in Zukunft die Schlafphasen einfach aus dem Herzrhythmus zu bestimmen. Vielleicht wird es in Zukunft auch möglich sein, aus Störungen des beobachteten Per-



■ Abb. 3: Tägliche Schlusskurse (linke Seite) und tägliche Renditen (rechte Seite) des Dow Jones Index, der IBM-Aktie und der Wechselrate zwischen britischem Pfund und US-Dollar.



■ Abb. 4: Veranschaulichung des iterativen Kaskadenprozesses. Nach jeder Iteration wird die Datensatzlänge verdoppelt. Ein Ausschnitt einer Reihe nach 21 Iterationen ist unten im Bild gezeigt.

sistenz-Schemas Rückschlüsse auf Herz-Kreislauf-Erkrankungen oder besondere Risiken für zukünftige Erkrankungen zu ziehen.

Finanzmärkte

Die zentralen Größen bei den Finanzmärkten sind die Preise von Aktien, Rohstoffen, Fremdwährungen und entsprechende Indices wie der DAX oder der Dow Jones Index, die nahezu sekundlich aufgelistet werden. In Abbildung 3 (linke Seite) sind die täglichen Schlusskurse des Dow Jones Index, der IBM-Aktie und der Wechselrate zwischen britischem Pfund und US-Dollar zu sehen. Man sieht deutlich, dass die Kurse nicht wie beim Klima um einen Mittelwert schwanken, sondern dass sie tendenziell vom Mittelwert wegzulaufen scheinen. Besser ist es daher, Kursdifferenzen zu betrachten, z.B. die der täglichen Schlusskurse. Auch die reinen Kursdifferenzen sind aber nicht die eigentlich interessierende Größe. Wenn man z.B. einen Euro Gewinn macht, sagt das alleine nicht viel aus. Hätte man nur einen Euro angelegt, so wäre der Gewinn hoch. Hätte man jedoch 1000 Euro angelegt, so wäre der Gewinn niedrig. Darum schaut man sich am

besten die Rendite an. Sie ist definiert als der tägliche relative Gewinn oder Verlust, bezogen auf den Einsatz (Abb. 3, rechte Seite). Man sieht, dass die Renditen stark schwanken. Abschnitte mit großen Gewinnen und riesigen Verlusten stehen Abschnitten gegenüber, in denen der Markt ruhig ist.

Im Gegensatz zu den Beispielen aus Klima, Hydrologie und Physiologie haben die Renditen selbst aber keine einfache Erhaltungsneigung. Auf große Renditen können sowohl große Gewinne als auch große Verluste folgen. Das heißt, auf den ersten Blick scheinen die Finanzmärkte kein Gedächtnis zu haben. Dies ist jedoch ein, auch in der Fachwelt verbreiteter, Irrtum. Bestimmt man die Beträge der Rendite (auch Volatilitäten genannt), indem man das Vorzeichen der negativen Renditen umkehrt (d.h. Gewinne und Verluste werden gleich behandelt), so sieht man sofort aus Abbildung 3 (rechte Seite), dass diese ein ausgeprägtes Berg-Tal-Verhalten zeigen, wie es für langzeitpersistente Reihen charakteristisch ist. Dieses Berg-Tal-Verhalten resultiert aus dem Herdenverhalten der Anleger, die von Gier und Angst getrieben sind: Bei steigenden Kursen kaufen immer mehr Leute Aktien, und bei fallenden Kursen ver-

kaufen immer mehr Leute ihre Aktien. Tatsächlich weisen die Volatilitäten ein ähnliches Gedächtnis auf wie globale Jahrestemperaturen im Klima mit einem γ -Wert von etwa 0,3. Da die Volatilitäten durch eine nichtlineare Operation aus den Renditen hervorgehen, wird hier das Gedächtnis auch als „nichtlineare Persistenz“ bezeichnet.

Das einfachste auch für den Laien zugängliche Modell, mit dem man die Renditen modellieren kann, ist das so genannte Kaskadenmodell (siehe Abb. 4). Hier wird eine synthetische Renditereihe iterativ numerisch erzeugt. Bei jeder Iteration wird die Länge der Reihe verdoppelt. Am Anfang besteht die Reihe aus einer Zahl, z.B. dem Wert Eins. Um diese Reihe zu verdoppeln wird dieser Wert mit zwei verschiedenen Zufallszahlen (aus einer Gaußverteilung mit Mittelwert 0) multipliziert. In den folgenden Iterationen wird die Datensatzlänge jeweils wieder verdoppelt, indem man, wie im ersten Iterationsschritt, jedem alten Wert durch Multiplikation zwei neue Werte zuordnet. Auf diese Weise entstehen Datensätze, die den Renditen ähneln und insbesondere deren nichtlineare Persistenz und Extremaleigenschaften in überraschend guter Weise reproduzieren [4].

Extremwertanalyse und Risikoabschätzung

Die Frage ist: Wozu ist die Persistenz gut? Und kann sie dazu dienen, das Risiko extremer Ereignisse wie Hochwasser (Abb. 5), Starkniederschläge,



■ Abb. 5: Hochwasserkatastrophe 1342 in Nürnberg (nach [5]).

Extremtemperaturen, Börsencrashes, etc. besser abzuschätzen? Dazu beschäftigen wir uns nun mit dem Auftreten von Extremereignissen und deren zeitlicher Abfolge.

Als Extremereignisse werden Ereignisse bezeichnet, die oberhalb einer gewissen Schwelle liegen und daher selten auftreten. Zur Untersuchung dieser Extremereignisse ist es sinnvoll, sich die Wiederkehrzeiten zwischen ihnen anzuschauen, also zwischen dem ersten und zweiten Ereignis, dem zweiten und dritten, dem dritten und vierten, usw.. Diese Wiederkehrzeiten bilden eine neue kürzere Datenreihe, die wesentliche Informationen über die Extreme enthält.

Die Größen, an denen man vorwiegend interessiert ist, sind die mittlere Wiederkehrzeit R , die Latenzzeit $\tau(t_E)$ und die Risikofunktion $W(t_E, \Delta)$. Falls seit dem letzten Extremereignis die Zeit t_E vergangen ist, gibt die Latenzzeit die mittlere Zeit bis zum nächsten Ereignis an, während die Risikofunktion die Wahrscheinlichkeit angibt, dass in der kommenden Zeitspanne Δ das nächste Extremereignis auftritt, z.B. am nächsten Tag oder in der nächsten Woche. Wenn man die Risikofunktion kennt, lässt sich ein Vorhersage-Algorithmus entwickeln, der einen Alarm auslöst, wenn ein Extremereignis vermutet wird. Man ist stets an einer

niedrigen Fehlalarmrate (=Anzahl der Fehlalarme pro normalem Ereignis) interessiert bei einer gleichzeitig hohen Trefferquote (=Anzahl der korrekten Alarme pro Extremereignis).


Falls die Originaldaten zufällig sind, ist die Latenzzeit $\tau(t_E)$ unabhängig von der seit dem letzten Extremereignis verstrichenen Zeit t_E und gleich der mittleren Wiederkehrzeit R , d. h. $\tau(t_E) = R = \text{konstant}$. Dies gilt auch für ganz große Zeitspannen, für die das nächste Ereignis rein intuitiv eigentlich längst überfällig wäre. Auch die Risikofunktion $W(t_E, \Delta)$ ist konstant und gleich Δ/R , solange der anvisierte Zeitraum Δ viel kleiner ist als die mittlere Wiederkehrzeit R . Präzisere Aussagen lassen sich nicht machen. Die Extremwerte treten rein zufällig auf. Dementsprechend haben auch die Wiederkehrzeiten dazwischen kein Gedächtnis. Daher lassen sich keine sinnvollen Vorhersagen machen. Stets ist die Trefferquote nur genauso groß wie die erlaubte Fehlalarmrate.

Im Falle langzeitpersistenter Daten ändert sich dieses Bild rapide. Aufgrund der Berg-Tal-Struktur der Originaldaten treten Extremwerte gehäuft in den Bergen und nur selten in den Tälern auf (siehe Abb. 1). Dies führt zu einer Anhäufung von sehr kurzen Wiederkehrzeiten bei den Bergen und sehr langen Wiederkehrzeiten bei den

Tälern. Die Wiederkehrzeiten weisen die gleiche Persistenz auf mit dem gleichen γ -Wert wie die Originaldatenreihe. Die Langzeitpersistenz kann somit beispielsweise die merkwürdige Anhäufung extremer Hochwässer im Mittelalter in Mitteleuropa, wie bei der Pegnitz (Abb. 6), befriedigend erklären. Das war früher nicht möglich.

Die Latenzzeit $\tau(t_E)$ ist beim Vorhandensein von Langzeitpersistenz keine Konstante mehr, sondern sie wächst mit der seit dem letzten Ereignis verstrichenen Zeit t_E an. Der Grund hierfür ist, dass je mehr Zeit verstrichen ist, die Wahrscheinlichkeit anwächst, dass man sich in einem Tal befindet, wo Extremwerte sehr unwahrscheinlich sind. Entsprechend ist auch die Risikofunktion $W(t_E, \Delta)$ keine Konstante mehr, sondern sie fällt mit der seit dem letzten Extremereignis verstrichenen Zeit t_E ab. Der Abfall ist umso stärker, je ausgeprägter die Erhaltungsneigung ist, d. h. je kleiner der γ -Wert ist. Entsprechend ist für sehr kleine Zeiten t_E die Risikofunktion größer und für sehr große Zeiten t_E kleiner als im zufälligen Fall. Diese Eigenschaft kann man zur verbesserten Prognose von Extremereignissen und damit zur Risikoabschätzung verwenden. Bei fester Fehlalarmrate kann nun die Trefferquote deutlich gesteigert werden. Sie ist aber noch nicht optimal. Die Unwägbarkeiten sind noch zu groß, um eine genaue Prognose zu erlauben.

Die Lage wird überraschenderweise besser im Falle von nichtlinearer Persistenz, wie sie bei den Renditen zu finden ist. Extremereignisse stellen nun große Verluste oberhalb einer gewissen Schwelle dar (z. B. mehr als 80% Verlust pro Tag/Woche oder Monat). Obwohl die Verluste zeitlich von-



■ Abb. 6: Historische Hochwässer der Pegnitz bei Nürnberg (nach R. Glaser [5]) in drei Kategorien eingeteilt. Man kann dieser Reihe ansehen, dass es offensichtlich Epochen (z. B. um 1440, 1570 und 1690 herum) gab, in denen binnen weniger Jahre viele Hochwässer eintraten.

einander unabhängig sind, besitzen doch die Wiederkehrzeiten zwischen ihnen eine erstaunliche Persistenz mit einem γ -Wert bei 0,3. Die Latenzzeit ist wieder eine anwachsende Funktion. Die Risikofunktion fällt umgekehrt proportional zur vergangenen Zeit t_E ab, schneller als im einfach persistenten Fall. Daher erlaubt die nichtlineare Persistenz hier eine präzisere Vorhersage (höhere Trefferquote bei fester Fehlalarmrate).

Die zentrale Größe in der Risikoabschätzung ist der so genannte „Value at Risk (VaR)“, der die (Verlust-) Schwelle beschreibt, die im nächsten Zeitraum nur mit einer fest vorgegebenen geringen Wahrscheinlichkeit p überschritten werden kann. Wird beispielsweise $p=1/100$ gewählt, so gibt der VaR den Verlust an, der am nächsten Tag/Woche oder Monat mit einer Wahrscheinlichkeit von 1% gemacht werden kann.

Generell ist der VaR die Umkehrung der Risikofunktion. Während man bei der Risikofunktion den Schwellwert q vorgibt und an der Wahrscheinlichkeit p interessiert ist, ein Ereignis oberhalb dieser Schwelle im nächsten Zeitraum anzutreffen, gibt man beim VaR die Wahrscheinlichkeit p vor und sucht die entsprechende Schwelle q .

Ist die Risikofunktion eine Konstante, wie im zufälligen Fall gleich Δ/R ,


dann ist auch der VaR zeitlich konstant und erlaubt keine Unterscheidung zwischen „ruhigen Zeiten“ (wo das Verlustrisiko gering ist) und „unruhigen Zeiten“ (wo das Verlustrisiko groß ist) und damit keine vernünftige Risikoabschätzung.

Im Fall nichtlinear persistenter Daten ist die Risikofunktion umgekehrt proportional zur Zeit t_E , die seit dem letzten Ereignis oberhalb q vergangen ist, mit einem Vorfaktor, der ebenfalls von q abhängt. Es ist eine leichte

mathematische Übung, aus der Risikofunktion den VaR zu bestimmen. Abbildung 7 zeigt den VaR des Dow Jones Index für 1500 Handelstage. Die dünne konstante Linie ist die Abschätzung, wenn man das Gedächtnis vernachlässigt. Die roten Punkte sind die Abschätzung des VaR unter der Ausnutzung der nichtlinearen Persistenz. Die Quadrate sind die real aufgetretenen Verluste oberhalb 1%. Man sieht, dass die roten Punkte die tatsächlichen Werte weitaus besser widerspiegeln, als es die Konstante tut, und damit zu einer deutlich verbesserten Risikoabschätzung führen.

Globale Klimaerwärmung

Die Erde hat sich in den letzten 100 Jahren um etwa $0,8^\circ\text{C}$ erwärmt, davon allein in den letzten 50 Jahren um ca. $0,6^\circ\text{C}$. Die Frage ist, inwieweit diese Anstiege noch im Rahmen der natürlichen Erhaltungsneigung des Klimas liegen, die wir zu Beginn dieses Artikels beschrieben haben, oder ob es einen von außen, beispielsweise vom Anstieg der Treibhausgase, herrüh-



■ Abb. 7: „Value at Risk“ des Dow Jones Index für den Schwellwert $p=1/100$, berechnet unter der Annahme zufälliger Daten (blau), und der Annahme von Daten mit nichtlinearem Gedächtnis (rot). Die Quadrate zeigen die Tagesverluste oberhalb 1% (nach M. I. Bogachev und A. Bunde: Phys. Rev. E, 80, 026131 (2009)).

renden Trend gibt. Darauf wollen wir nun eingehen.

Den Temperaturanstieg in einem betrachteten Zeitraum bestimmt man üblicherweise, indem man eine optimale Gerade an die Daten anpasst („lineare Regression“) und dann deren Differenz zwischen Anfangs- und Endwert misst. Wie bei den Renditen interessieren wir uns hier weniger für den Absolutwert als vielmehr für den relativen Temperaturanstieg. Diesen

erhält man, indem man die Standardabweichung der Daten um die angepasste Gerade bestimmt und dann den gemessenen Temperaturanstieg durch diese dividiert. Schwanken die Daten nur wenig um die Gerade, so ist der relative Anstieg deutlich größer, als wenn sie stark um die Gerade schwanken. Wir wissen, dass die Temperaturreihen eine natürliche Erhaltungsneigung haben, die nur langsam mit der verstrichenen Zeit abfällt und

allein durch den γ -Wert charakterisiert wird. Unsere zentrale Frage reduziert sich daher auf das Problem, wie groß die Wahrscheinlichkeit $W_\gamma(x)$ ist, dass allein aufgrund der natürlichen Erhaltungsneigung ein relativer Anstieg größer ist als ein vorgegebener Wert x .

Falls diese Wahrscheinlichkeit $W_\gamma(x)$ für einen gemessenen Temperaturanstieg x größer ist als eine gewisse Schwelle q (oft wird $q=2,5\%$ gewählt), dann kann der Anstieg noch als natürlich angesehen werden. Ist $W_\gamma(x)$ hingegen kleiner als q , so gehen wir von einem unnatürlichen Anstieg aus.

Im letzten Jahr ist es uns gelungen, $W_\gamma(x)$ mit Hilfe von Computersimulationen, bei denen die Temperaturreihen mit ihrem γ -Wert nachgestellt wurden, und Methoden, die früher an unserem Institut entwickelt worden sind, zu bestimmen. Das Ergebnis lässt sich in eine bemerkenswert einfache Formel packen, die beschreibt, wie $W_\gamma(x)$ mit wachsendem x und/oder wachsendem γ -Wert abnimmt. Für mathematisch Interessierte verweisen wir auf die Originalarbeit [6].

Mit Hilfe dieser Formel lassen sich nun beliebige lokale und global gemittelte Temperaturreihen auswerten. Die globalen Reihen werden z. B. vom Hadley-Centre in England zur Verfügung gestellt. Wir beschränken uns auf gemittelte Reihen der Nordhalbkugel, da diese aufgrund der besseren Datenlage zuverlässiger erscheinen als die der Südhalbkugel. Die See- und Landdaten haben sich in den letzten 100 Jahren um etwa $0,65^\circ\text{C}$, bzw. $0,94^\circ\text{C}$ erhöht. Zu beachten ist, dass bei den Landdaten, die zum Teil auf städtischen Temperaturreihen beruhen, auch Urbanisierungseffekte zu dem Temperaturanstieg von $0,94^\circ\text{C}$ beigetragen haben. Die Wahrscheinlichkeit, dass natürliche Anstiege oberhalb dieser Werte auftreten, liegt bei den Seedaten bei etwas mehr als 4% (d. h. deutlich oberhalb von

DIE AUTOREN

Sabine Lennartz, Jahrgang 1980, studierte in Köln Physik und begann 2006 ihr Promotionsstudium in Theoretischer Physik bei Prof. Armin Bunde in Gießen. 2008 erhielt sie den Outstanding Student Paper Award der Nonlinear Geophysics Focus Group auf dem Fall Meeting der American Geophysical Union (AGU). 2009 wurde



sie mit einer Arbeit zum Thema: „Korrelations- und Trendanalyse in kurzen Zeitreihen: Anwendungen in Klimatologie und Seismologie“ mit „summa cum laude“ promoviert. Sie ist wissenschaftliche Mitarbeiterin am

Institut für Theoretische Physik der Universität Gießen und forscht auf dem Gebiet der interdisziplinären Zeitreihenanalyse.

Armin Bunde, Jahrgang 1947, studierte in Gießen und Stuttgart Physik und habilitierte sich, nach längeren Forschungsaufenthalten in Antwerpen und Saarbrücken, 1982 in Theoretischer Physik an der Universität Konstanz. 1984 erhielt er ein Heisenberg-Stipendium, das es ihm ermöglichte, in Boston, Paris und Tel Aviv wissenschaftlich zu arbeiten. Ebenfalls 1984 erhielt er den Carl-Wagner Preis. Von 1987 bis 1993 war er Professor an der Uni-



versität Hamburg, seit 1993 ist er am Institut für Theoretische Physik in Gießen tätig. Sein Arbeitsfeld umfasst neben der klassischen Festkörperphysik die interdisziplinäre Statistische Physik, mit Anwendungen in den Geo-, Lebens- und Finanz-

wissenschaften. In jüngster Zeit interessiert er sich verstärkt für Extremereignisse und deren Gesetzmäßigkeiten sowie für komplexe Netzwerke.

2,5%), und bei den Landdaten bei etwa 0,03% (also deutlich unterhalb von 2,5%). Der Anstieg der Seetemperaturen kann somit noch natürlichen Ursprungs sein, während dies bei den Landtemperaturen praktisch ausgeschlossen ist. Der Grund dafür ist, dass die Seedaten unter anderem aufgrund der Trägheit der Meere, die als Wärmespeicher dienen, eine viel höhere Erhaltungsneigung aufweisen als die Landdaten und somit auch große Anstiege auf natürliche Weise möglich sind. Hätten die Landtemperaturen nur im gleichen Maße wie die Seetemperaturen zugenommen, so wäre auch dieser Anstieg mit $W_j(x) \approx 0,4\%$ ebenfalls deutlich unterhalb der Signifikanzschwelle von 2,5%.

Für lokale Landstationen sind die Ergebnisse nicht eindeutig. Signifikante Trends mit $W_j(x) < 0,01\%$ sieht man auf den Bergspitzen, beispielsweise auf dem Sonnblick in Österreich, aber auch in Zentral-Asien, beispielsweise in Irkutsk. Auf dem flachen Land in Deutschland, wie z. B. in Potsdam, wo durchaus noch Urbanisierungseffekte zum Temperaturanstieg von 0,73°C beigetragen haben, ist $W_j(x) > 4\%$, d. h. die Temperaturerhöhung muss nicht der anthropogenen globalen Erwärmung angelastet werden. Bei Plymouth in England oder in Charleston in den USA hingegen sind die Temperaturen nur um 0,01°C bzw. 0,06°C angestiegen, was in beiden Fällen zu einer Wahrscheinlichkeit $W_j(x)$ von etwa 42% führt, d.h. es gibt hier keine Indizien für eine anthropogene Temperaturerhöhung.

Universalität

In dieser Arbeit haben wir ganz unterschiedliche komplexe Systeme betrachtet, welche die Eigenschaft der Langzeitpersistenz eint, und haben daraus wertvolle Rückschlüsse auf die Systeme gezogen. Mit Hilfe der Langzeitpersistenz konnten wir

beispielsweise die Schlafphasen neu charakterisieren, Gesetzmäßigkeiten beim Klima aufdecken, eine Erklärung für die Häufung von Extremereignissen liefern und das Ausmaß des menschlichen Anteils an der globalen Erwärmung abschätzen. Bei den Finanzmärkten führt die (nichtlineare) Persistenz zu verbesserten Risikoabschätzungen. Darüber hinaus ermöglicht die beobachtete Persistenz, Modelldatensätze oder Datenrekonstruktionen zu testen: Falls die Persistenz falsch wiedergegeben wird, kann das Modell/die Rekonstruktion hinterfragt werden. Die hier geschilderte Vorgehensweise ist typisch für die interdisziplinäre Forschung in der Statistischen Physik, bei der ganz verschiedene Systeme aus einem ähnlichen Blickwinkel betrachtet werden. Man erhofft sich davon, „universell“ gültige Gesetzmäßigkeiten zu finden, die es erlauben, aus dem Verhalten eines Systems auf das Verhalten anderer Systeme schließen zu können.

Zum Schluss möchten wir uns bei der Deutschen Forschungsgemeinschaft und bei der Europäischen Union (Forschungsprojekte DYSONET und DAPHNET) für die großzügige finanzielle Unterstützung bedanken, die einen Teil der hier vorgestellten Arbeiten erst ermöglichte. •



LITERATUR

- [4] **M. I. Bogachev und A. Bunde:** Phys. Rev. E 78, 036114 (2008)
- [5] **R. Glaser:** Klimageschichte Mitteleuropas, 1000 Jahre Wetter, Klima, Katastrophe, Wiss. Buchgesellschaft, Darmstadt (2001)
- [6] **S. Lennartz und A. Bunde:** Geophys. Res. Lett. 36, L16706 (2009)
-
- Dr. Sabine Lennartz**
Prof. Dr. Armin Bunde
 Justus-Liebig-Universität Gießen
 Institut für Theoretische Physik
 Heinrich-Buff-Ring 16 • 35392 Gießen
 Telefon: 0641 99-33360
 E-Mail: armin.bunde@uni-giessen.de,
 sabine.lennartz@theo.physik.uni-giessen.de
-
- [1] **E. Koscielny-Bunde, A. Bunde, S. Havlin, H. E. Roman, Y. Goldreich und H.-J. Schellnhuber:** Phys. Rev. Lett., 81, 729 (1998).
- [2] **R. B. Govindan, D. Vyushin, A. Bunde, S. Brenner, S. Havlin und H.-J. Schellnhuber:** Phys. Rev. Lett. 89, 028501 (2002)
- [3] **A. Bunde, S. Havlin, J. W. Kantelhardt, T. Penzel, J.-H. Peter und K. Voigt:** Phys. Rev. Lett. 85, 3736 (2000).